

## FCM에 기반한 자가생성 지도학습알고리즘을 이용한 전력선의 고장전류 판별

정종원\*, 원대현\*, 이준탁\*\*  
동의과학대학\*, 동아대학교\*\*

### Fault Current Discrimination of Power Line using FCM allowing self-organization

Jong-Won Jeong\*, Tae-Hyun Won\*, Joon-Tark Lee\*\*  
Donggeui Institute of Technology\*, Dong-A University\*\*

**Abstract** - This article suggests an online-based remote fault current mode discrimination method in order to identify the causes of the power line faults with various causes. For that, it refers to existing cause identification methods and categorizes modes by fault causes based on statistical techniques beforehand and performs the pretreatment process of fault currents by each cause acquired from the fault recorder into a topological plane in order to extract the characteristics of fault currents by each cause. After that, for the fault mode categorization, it discriminates modes by each cause using data by each cause as leaning data through utilizing RBF network based on FCM allowing self-organization in deciding the middle layer.

And then it tests the validity of the suggested method as applying it to the data of the actual fault currents acquired from the fault recorder in the electric power transmission center.

#### 1. 서 론

급속한 산업발달과 경제성장으로 인하여 국내의 전기 에너지 수요가 급증함에 따라 전력설비의 용량이 증가하고 있다. 뿐만 아니라 대도시의 인구 집중 현상에 따른 전력 수요 밀도가 크게 증가하는 시점에서 전력의 안정적인 공급은 매우 중요한 문제가 된다. 그러나 이러한 전력계통은 그 시스템이 외부에 노출이 되어 있기 때문에 자연 재해나 여러 가지 원인에 의해서 고장이 발생하게 되며, 이는 전력의 안정적인 공급이라는 측면에서 문제가 되므로 전력계통의 고장에 대한 해석, 복구, 계통 보호 및 사고 시에 그 원인을 규명하는 문제는 아주 중요한 관심사가 되어 진다.

그 중 고장의 원인을 규명하는 것은 사고로부터의 계통의 신속한 복구와 정전구역의 확대를 막기 위해 정확하고 신속하게 이루어져야 하지만 현재까지의 고장 원인 규명은 주로 숙련된 전문가의 경험 및 보조 프로그램(protas, PSSE) 등에 의하였다. 그러나 이는 계통에 대하여 전문적인 지식을 가진 전문가에 의존하기 때문에 해석을 하는 주체에 따라 그 원인 규명의 정도가 달라지고 애자파손 혹은 단선 등의 제투입이 불가능한 사고가 아닌 경우에는 대부분이 수 사이클[Cycle] 내에 복구가 되어지므로 정확한 고장 원인의 판별이 어려워지게 된다.

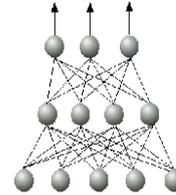
본 논문에서는 이러한 다양한 원인을 가진 전력선의 고장에 있어 그 원인을 판별하기 위하여 기존의 원인 판별을 위한 방법을 기저로 하여 우선 통계적 기법에 의하여 고장 원인별 모드를 분류하였고 각 원인별 고장 전류의 특징점을 추출하기 위하여 고장 기록 장치로부터 획득된 원인별 고장 전류를 위상 평면으로의 전처리 과정을 수행하여 기존의 방법과 비교하였다. 그리고 일반적인 RBF 네트워크에서는 입력 데이터가 중간층의 임의의 하나의 클러스터에 대해 거리에 기반한 속속도를 기준으로 하여 속하거나 속하지 않는 이분법에 의해 분류되어지는 것에 대하여 제안하는 방법에서의 중간층의 클러스터링 방법은 기존의 이분법과는 달리 퍼지 분류인 1개의 데이터가 2가지 이상의 클러스터에 속하는 것을 허용한다. 이는 퍼지 논리의 특징을 이용하여 이분법에 의한 ART 알고리즘을 적용한 방법보다 효율적이고 정확성이 높은 중간층을 구성하기 위함으로 본 논문에서는 FCM 알고리즘에 기반한 자가 생성 지도 학습 알고리즘을 이용한다. 이후 제안된 기법을 전력관리처에서 실제 획득되어진 고장 기록 장치의 실제 고장 전류의 데이터에 적용하여 이의 유효성을 검증하였다.

#### 2. FCM based Radial Basis Function Network

##### 2.1 Radial Basis Function Network

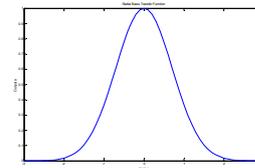
RBF 네트워크는 빠른 학습 속도, 일반화, 단순화의 특징으로 데이터 분류, 비선형 시스템 모델링 등에 많이 적용되고 있다. 신경망의 관점에

서 RBF네트워크는 3개의 층으로 구성된 전방향 신경망 형태를 갖추고 있다. 이런 구조적 형태의 특징으로 각 계층이 개별적인 순서를 결정하기 때문에 학습 속도가 다층 퍼셉트론 보다 빠른 특징을 가지고 있다. 기존의 오류 역전파 학습 알고리즘과 같은 다층 퍼셉트론(multilayer perceptron)의 연결 가중치들이 지역 최소화에 위치하여 학습 패턴들이 잘 분류되지 않은 경우를 방지할 수 있으며 학습 시간을 단축시킬 수 있다. 전형적인 RBF 네트워크의 구조는 그림 1과 같다.



〈그림 1〉 RBF Network

그림 1로 표현되는 RBF 네트워크의 구조에서 입력층과 중간층간에는 클러스터링하는 역할을 수행하게 된다. 즉, 이 층의 목적은 주어진 자료 집합을 유사한 클러스터들(homogeneous cluster)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터로 분류하고 정해진 반경 내에 존재하지 않으면 다른 클러스터로 분류한다[45]. 중간층에 있는 노드는 그 자신의 중심을 가지고, 입력  $X = \{x_1, x_2, x_3, \dots, x_n\}$ 에 대하여 자신과의 중심 간의 거리 벡터를 구한다. 이 노드의 출력은 거리 벡터에 대한 일정 형태의 비선형 함수로 얻어진다. 입력이 노드의 중심에 가까울수록 그 출력값은 커지게 된다. 중심을 0으로하고 폭을 좌우 3으로 하였을 경우의 RBF 네트워크 출력층 전달함수는 다음 그림 2와 같고 중간층을 구하는 것은 식 (1)과 같다.



〈그림 2〉 Radial Basis Transfer Function

$$o_k = \exp\left(\frac{-\|X - C_k\|^2}{\sigma_k^2}\right) \quad (1)$$

여기서  $c$ 는 각 클러스터의 중심값이고  $\sigma$ 는 중심에 대한 넓이 값이 된다. 중간층과 출력층간에는 일반화된 델타학습을 적용한다. RBF 네트워크의 출력노드는 각 중간층 노드의 출력값에 학습과정 중 가변인 연결 가중치를 곱한 후 이들을 더한 값을 그 출력값으로 갖는다. 그리고 식 (2)와 같이 지도학습과 동일한 형태로서 목표값과 출력값 간의 오차값을 최소화하는 방향으로 학습한다.

$$y_i = \sum_{k=1}^M o_k w_{kj} \quad (2)$$

그러나 정해진 반경 내에서 클러스터링 하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF

네트워크의 전반적인 효율성에 큰 영향을 준다. RBF 네트워크는 학습이 완료된 상태, 즉 연결 강도가 특정값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습 시키는데 상당한 학습 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴들이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류하여 인식률을 저하시킨다. 그리하여 이러한 문제점을 해결하기 위한 노력으로 다음과 같은 연구가 수행되었다.

### 2.1.1. ART2 기반 RBF 네트워크

ART2 기반 RBF 네트워크는 중간층을 생성하는 과정에서 경계 변수의 설정에 따라 중간층의 노드 수가 결정된다. 경계 변수는 클러스터를 분류하는 반지름 값이다. 경계 변수를 적게 설정하면 입력 패턴과 저장 패턴 사이에 약간의 차이만 있어도 서로 다른 패턴으로 분류하여 새로운 클러스터를 생성하고 경계 변수를 크게 설정하면 입력 패턴과 저장 패턴 사이에 많은 차이가 있어도 같은 패턴으로 분류한다. 따라서 경계 변수의 설정에 따라 학습과 인식 성능이 달라지는 문제점이 있다.

### 2.1.2 퍼지 C-Means 기반 RBF 네트워크

퍼지 C-Means 기반 RBF 네트워크는 중간층을 생성하기 위하여 퍼지 C-Means 알고리즘을 적용한다. 문자 인식 분야에 이 알고리즘을 적용할 경우에는 학습 시간이 많이 소요되는 단점이 있다. 일반적으로 문자 인식이 있어서 입력 패턴은 이전 패턴을 사용한다. 따라서 0과 1로 구성된 학습 패턴을 퍼지 C-Means 알고리즘을 적용할 경우에는 정확히 입력 패턴들을 분류하기 어렵고 다른 클러스터링 알고리즘에 비해 학습 시간이 많이 소요된다.

## 2.2 FCM

FCM 알고리즘은 소속도와 명기된 정보에 따라 각 데이터를 클러스터로 구성하는 것으로 n개의 벡터  $X_i$ 를 c개의 퍼지 집합으로 나누고 각 집합의 클러스터들의 중심을 찾는 것이다. 식 (3)은 정규화를 규정하기 위하여 소속도를 나타내며 소속도의 합은 항상 1이 된다.

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n. \quad (3)$$

여기서  $u_{ij}$ 는 0과 1사이의 값으로 소속도를 나타낸다.  $G_i, i = 1, \dots, c$ 라고 할 때, n개의  $X_i$  집합의  $X_k$  벡터와 클러스터의 중심인  $c_i$  사이의 차이를 측정하는 유클리드 거리와 그 목표함수는 식 (4)와 같다.

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left( \sum_{k: x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (4)$$

$$\mathcal{J}(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (5)$$

여기서  $d_{ij} = \|c_i - x_j\|$ 는 j 번째 정보와 i 번째 클러스터 중심값 사이의 유클리드 거리이고  $m \in [1, \infty)$ 은 가중치이다. 식 (5)가 최소값이 되기 위한 필요조건은 식 (6)과 같다.

$$\begin{aligned} \bar{\mathcal{J}}(U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) &= \mathcal{J}(U, c_1, \dots, c_c) + \sum_{j=1}^n \lambda_j \left( \sum_{i=1}^c u_{ij} - 1 \right) \\ &= \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 + \sum_{j=1}^n \lambda_j \left( \sum_{i=1}^c u_{ij} - 1 \right) \end{aligned} \quad (6)$$

여기서  $\lambda_j$ 는 라그랑지 곱셈자(Lagrange multiplier)이다. 식 (6)에서 최소가 되기 위한 조건은 다음과 같다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{k=1}^n \left( \frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (7)$$

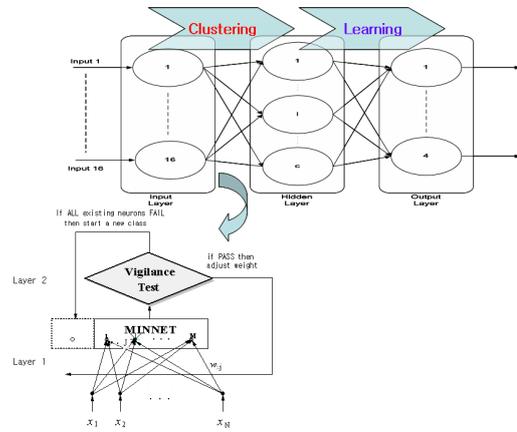
$$u_{ij} = \frac{1}{\sum_{k=1}^c \left( \frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (8)$$

FCM 알고리즘은 식 (7), 식 (8)의 조건이 만족하도록 계속 반복한다.

## 2.3 FCM based Radial Basis Function Network

지금까지 살펴본 바와 같이 논문의 대상이 되는 고장 원인의 판별의 경우 고장 전류 패턴의 학습데이터가 있으므로 지도학습이 가능해야하고, 원인 모드별 분류에서 통계적인 특성에 의해 분류하였으므로 데이터의 패턴 특성이 반영되지 않았을 수도 있으며, 학습되지 아니한 다양한 형태의 고장 전류 모드가 있을 수 있으므로 자가 생성이 가능한 학습 알고리즘이 요구된다. 따라서 감독학습의 특징을 지니고, 빠른 학습 속도와 일반화, 단순화의 특징을 가진 데이터 분류, 비선형 시스템 모델링 등에 많이 적용되고 있는 전방향 신경망 형태의 RBF 네트워크와 무감

독학습의 형태를 지니지만 신경망에 학습되지 않은 전혀 새로운 형태의 패턴이 들어오는 경우에도 이전에 학습된 유사한 패턴으로 분류해 버리는 문제점들을 해결하기 위해 학습되지 않은 새로운 패턴이 들어오면 새로운 클러스터를 형성함으로써 기존 패턴에 영향을 주지 않게 하는 FCM에 기반한 RBF 네트워크를 고장 전류의 모드를 판별하기 위하여 적용하였다. 이를 그림 3으로 나타내었다.



〈그림 3〉 FCM based Radial Basis Function Network

## 3. 결 론

FCM에 기반한 자가생성 지도학습알고리즘에 의한 고장 전류 모드의 판별 결과는 다음과 같다.

〈표 1〉 Result of FSOSL

원 인	세 부 원 인	인 식 율	
		학습 데이터	비학습 데이터
자연재해	낙뢰	20/20	28/30
	섬락	18/20	23/30
	폭설 및 폭우	10/10	15/20
	기타(산불 등)	16/20	20/30
이물접촉	수목 및 조류 접촉	19/20	28/30
	비래물 접촉	20/20	21/30
설비고장	기타(점지공사, 크레인 등)	10/10	10/20
	설비결함(절연파괴)	20/20	28/30
	파급고장	17/20	10/30
	기타(오동작)	20/20	30/30
	계	171/180 (95%)	209/280 (74%)

시뮬레이션 결과 학습된 데이터에 관해서는 약 95%, 비학습된 데이터에 대하여서는 약 74%의 판별율을 보였다. 학습된 데이터에서의 판별하지 못한 부류는 모드 2와 모드 4, 그리고 모드 9이었는데 모드 2의 경우는 2 모선에 모두 사고가 난 형태로써 이때 데이터의 유사성이 떨어지는 것으로 나타났다. 모드 4의 경우는 기타 범주의 고장 원인이 산불 등과 그외의 데이터들과의 상관성이 떨어짐에 기인하는데 다른 모드로의 결과가 유도되는 것으로 보아 분류에 문제가 있었던 것으로 보인다. 모드 9의 경우는 파급고장에 의한 것으로 주변의 다른 원인의 파급에 의한 것이다. 이는 데이터의 형태의 유사성이 중성선 전류의 크기가 작아짐은 판별을 해 내는데 그렇지 않은 경우는 1차적인 원인으로의 분류를 행할 수 있었다. 뿐만 아니라 비학습된 데이터의 경우에는 그 인식율이 저하되었는데 이는 학습된 데이터와 비학습된 데이터의 상관성이 떨어지거나 혹은 충분히 학습이 되지 못한 결과이다.

### [참 고 문 헌]

- [1] Aucoin B.M., Russell B.D., "Distribution High Impedance Fault Detection Utilizing High Frequency Current Components", IEEE Trans. on Power Apparatus and Systems Vol. Pas-101, NO. 6, pp. 1596-1606, June 1982.
- [2] 이준탁, 정종원, "웨이블릿 변환을 이용한 전력시스템 고장전류의 판별", 조명·설비학회 논문지, 제21권 3호, pp.75-81, 2007, 3월.
- [3] Martin T. Haugan, "Neural Network Design", PWS Publishing Company, 1996.